

3次元脳MRI画像の類似症例検索システムのための 深層距離学習を用いた優れた低次元表現の獲得

音賀優颯[†] 藤山真悟[†] 新井颯人[†] 茶山祐亮[†] 彌富仁[†] 大石健一[‡]

[†]法政大学 理工学部 応用情報工学科

[‡]Department of Radiology and Radiological Science
Johns Hopkins University School of Medicine

概要

医療現場において類似症例検索は主に診断支援のため日常的に利用される。我々はこれまで3次元の脳MRI画像の類似症例検索実現を目的に、その前段として3D-convolutional autoencoder(CAE)を用いた次元削減技術を提案し、500万次元程度のデータを150次元まで圧縮することに成功した。しかし実用的な低次元表現は、被験者の個体差より病気の特徴を重視する必要がある、改善の余地が残されていた。本報告では、3D-CAEに距離学習の概念を導入することで、より優れた低次元表現の獲得と、それらを用いた症例のクラスタリング結果について報告する。

1 はじめに

脳MRI画像とそれに対応する診療データからなるビッグデータは病気の診断支援などを目的とした活用が強く期待されている。現行システムの症例検索には文字列検索が利用されているため、症例登録時には画像に適切な注釈の付与、検索時には適切な条件指定などの困難さが問題視されている。そのため文字列検索に代わり入力症例画像の特徴に基づき検索を行うContent-based image retrieval(CBIR)の活用が期待されている[1]。しかし、3次元脳MRI画像のような次元数が非常に大きいデータは過学習を引き起こすため、汎化性のあるシステム構築のためには次元削減が必須となる。この問題を解決するために我々は3D-CAEを用いた次元削減技術を提案し、重要な医療情報のある程度保存しながら約500万次元のデータを150次元まで圧縮す

ることに成功した[2]。しかし、この手法では被験者の個体差に依存する画像特徴に大きく影響される傾向が見られ、実用的な類似症例検索システム実現は改善が必要であった。そこで本報告では、病気に由来する特徴をより効率的に保存しつつ、次元圧縮を行うモデルを構築するため、圧縮された特徴空間において同一疾患同士の特徴量のユークリッド距離を小さくする制約を設ける深層距離学習[3]のアイデアを3D-CAEに導入するモデルを提案する。実験により、症例の低次元表現を用いたクラスタリング結果および、入力画像と再構成画像のRoot mean squared error(RMSE)からその有用性を評価した。

2 方法

2.1 データセットと前処理

本研究で使用したデータセットはADNI2データセット¹として公開されている。Cognitively normal(CN) 1121症例とAlzheimer's disease(AD) 674症例に対して脳領域の抽出と、Affine変換による位置と大きさの補正を行うMRICloud²を適用した。また、MRI画像を機械学習を用いて解析する研究では一般に画像の低解像度変換が行われており、本研究においても3D-CAEの処理効率化のため80×96×80 pixelsへトリサイズを行った。評価は学習データに含まれる患者が検証データに含まれないgroup 5-fold cross validationにより行った。

2.2 3D-CAEの損失関数

今回の実験においても3D-CAEを用いて症例を150次元に圧縮する。これまでは3D-CAEをその入出力画像のMean squared error(MSE)を損失関数にして学習を行ってきた。今回はこの損失に深層距離学習のアイデアを導入し、同一ラベルの特徴表現同士のユーク

Efficient feature embedding of 3D brain MRI images for content-based image retrieval with deep metric learning

[†]Yuto ONGA, Shingo FUJIYAMA, Hayato ARAI, Yusuke CHAYAMA, Hitoshi IYATOMI (Hosei University) and [‡]Kenichi OISHI (Department of Radiology and Radiological Science, Johns Hopkins University School of Medicine)
yuto.onga.3u@stu.hosei.ac.jp

¹<http://adni.loni.usc.edu/datasamples/mri>

²<https://www.mricloud.org>

リッド距離を小さく，別ラベルの特徴表現同士の距離を大きくする制約 [3] を追加した．疾患のラベル (CN or AD) が付与された各データ x と，各疾患 (c クラス) からサンプリングされたデータ z_i ($i \in \{1 \dots c\}$) それぞれの低次元表現を獲得し，それらのユークリッド距離を算出する．その符号を反転させたものをソフトマックス関数の入力に用い，出力 P を得る．

$$P(x; z_1, \dots, z_c)_i = \frac{e^{-\|F(x)-F(z_i)\|^2}}{\sum_{j=1}^c e^{-\|F(x)-F(z_j)\|^2}}, i \in \{1 \dots c\}$$

x が属するクラスを 1 それ以外を 0 で構成する長さ c の one-hot ベクトル I と P のクロスエントロピーをとることで，クラスごとのデータ表現に基づく損失 L を求める．

$$L(x, z_1, \dots, z_c) = H(I(x), P(x; z_1, \dots, z_c))$$

最終的な損失関数 E は損失 L の強さを調整するための係数 α (> 0) をかけて MSE に加算する． α は今回の実験では 1 に設定した．

$$E = MSE + \alpha L(x, z_1, \dots, z_c)$$

これにより疾患に関する特徴を明示的に圧縮した特徴量に保存することができるため，疾患分類能の高い圧縮特徴の獲得が期待できる．

3 結果と考察

MSE のみを損失関数とした従来モデルと提案手法を用いたモデルそれぞれの学習を行い，検証用データにおいて得られた圧縮特徴量を用いて K-means クラスタリングにより CN と AD の分類精度を評価した．結果，従来手法では $0.547 (\pm 0.032)$ ，提案手法では $0.786 (\pm 0.087)$ の精度となった．また，クラスタリング時の特徴量の分布を t-SNE [4] により 2次元空間に射影した結果を図 1 に示す．また，検証用データの入力画像と再構成画像のスライスの例を図 2 に示す．従来手法と，提案手法の再構成画像の RMSE はそれぞれ 6.49% と 7.11% であった．図 1 から既存手法により得られた低次元表現は疾患に関係なく分布しているのに対して，提案手法により得られる低次元表現は疾患に関してある程度偏りながら分布していることが目視により確認できる．また，クラスタリング結果と図 2 より MSE のみを損失関数にする従来の CAE モデルでは画像の再現性は若干高いが，AD と CN のクラスタリングが事実上できていない．一方で，提案する距離学習を併用する CAE モデルは優れたクラスタリング結果を示し，CBIR に適した特徴を獲得できていると言える．

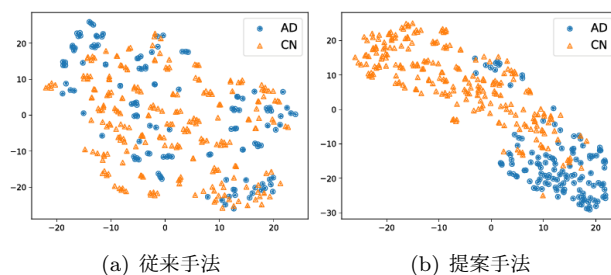


図 1: 中間表現の分布




図 2: MRI 画像の 1 スライス (a) と CAE により得られる再構成画像の 1 スライス (b, c)

4 おわりに

3D-CAE を用いて脳 MRI 画像を低次元へ圧縮する際，深層距離学習を用いて疾患の特徴に注目するような損失関数を導入することで，これまでの手法とほぼ同様の圧縮表現を得ながらクラスタリングにおいて明らかに分類能が高い結果が得られた．

参考文献

- [1] A. Kumar, J. Kim, W. Cai, M. Fulham, and D. Feng, “Content-based medical image retrieval: A survey of applications to multidimensional and multimodality data,” *Journal of Digital Imaging*, vol. 26, no. 6, pp. 1025–1039, 2013.
- [2] H. Arai, Y. Chayama, H. Iyatomi, and K. Oishi, “Significant dimension reduction of 3d brain mri using 3d convolutional autoencoders,” *IEEE Proc. EMBC*, pp. 5162–5165, 2018.
- [3] E. Hoffer and N. Ailon, “Semi-supervised deep learning by metric embedding,” *CoRR*, vol. abs/1611.01449, 2016.
- [4] L. v. d. Maaten and G. Hinton, “Visualizing data using t-sne,” *Journal of machine learning research*, vol. 9, pp. 2579–2605, 2008.